# 二层分解技术在电价预测中的应用研究 *

殷　豪，曾　云，黄圣权，董　朕

(广东工业大学，广州 510006)

**摘　要：**针对电价波动幅度大且预测精度低的问题，提出了二层分解技术与神经网络组成的电价多步预测模型。该模型首先采用集合经验模式分解将原始电价序列分解为一系列分量，变分模态分解将第一层分解产生的最高频率分量进一步分解为一系列模态分量,所有分量采用神经网络模型进行预测,并使用纵横交叉算法对神经网络的参数进行优化，最后叠加所有子序列，得出预测电价值。仿真结果表明，所提出的模型相比其他混合模型具有更好的预测性能，且实用价值高。

**关键词：**二层分解；纵横交叉算法；多步预测；神经网络；电价预测

**中图分类号：**TM73　　doi: 10.3969/j.issn.1001-3695.2017.09.0925

## Research on two-layer decomposition technique for predicting electricity price

Yin Hao, Zeng Yun, Huang Shengquan, Dong Zhen

(*College of Automation Guangdong University of Technology*, *Guangzhou* 510006, *China*)

**Abstract:** To solve the problems that the electricity price has a lot of volatility and a low accuracy , this paper proposes a multi-step prediction model composed of two-layer decomposition technique and back propagation neural network(BP) . Firstly, variational mode decomposition(VMD) is specifically applied to further decompose the high frequency intrinsic mode functions (IMFs) generated by ensemble empirical mode decomposition(EEMD) into a number of modes. Next, BP model optimized by crisscross optimization algorithm(CSO) algorithm is utinized to forecast all sub-sequences, and the forecast series of electricity price is obtained by adding up all sub-sequences. The simulation result shows that the proposed model has superior performances for other hybrid models , and it has a great practical values.

**Key Words:** two-layer decomposition; crisscross optimization algorithm; multi-step prediction, neural network; electricity price prediction



## 0　引言

电能是当今世界必不可少的绿色无污染能源，在人们日常生活中扮演着重要角色。在电力市场竞争越来越激烈的情况下，电力可以像货物一样在市场环境下自由交易，因此电价在很大程度上反映了电力市场的供求关系。由于电价受负荷、天气、商务交易、日常活动以及发电侧报价等人为因素的影响，使得电价具有随机性、不稳定性、非线性的复杂特点[1]，故建立精准的电价预测模型面临着巨大的挑战。电价波动大小与电力市场风险紧密相关[2]，因此，准确的电价预测对于电力系统和电力市场具有重要的意义。

电价预测方法分为二类，一类是通过寻找自变量与预测值因果关系的因果关系预测法[3]，另一类是时间序列法，此方法是假设预测值和历史电价相关联。如上所述，在实际生活中，电价受很多复杂因素影响，因此考虑到用因果关系预测法具有一定的难度，所以许多研究人员转向使用时间序列法进行电价预测[4]。最常用的时间序列法分为：统计模型[5]、混合模型[6]、人工智能模型。而现已有大量人工智能法应用于不同的预测领域，如人工神经网络[7]、BP、支持向量机[8]（support vector machine，SVM），如文献[9]使用粒子群算法（particle swarm optimization，PSO）对神经网络的阈值和权值进行优化，来提高神经网络的预测能力，并提出了 PSO-BP 的边际电价预测模型。将优化的神经网络模型和未优化神经网络模型的计算结果进行比较分析，可知优化后的模型预测结果和实际数据相差更小。对神经网络参数优化是一个大规模多峰优化问题，PSO 算法在优化时存在收敛速度慢、易陷入局部最优等弊端。

由于很多数据系列具有非平稳性和非线性的特点，如电价、风速、负荷等，然而单一预测模型已不能精准预测复杂的数据

---

**基金项目：**广东省科技计划资助项目（2016A010104016）；广东电网公司科技项目（GDKJQQ20152066）

**作者简介：**殷豪（1972-），女，副教授，硕导，主要研究方向为电力系统稳定与控制（3403446@qq.com）；曾云（1994-），女，硕士研究生，主要研究方向为人工智能算法在电力系统中的应用；黄圣权（1991-），男，硕士研究生，主要研究方向为人工智能算法在电力系统中的应用；董朕（1990-），男，硕士研究生，主要研究方向为人工智能算法在电力系统中的应用.

系列。因此很多学者一直努力使用不同的分解技术去处理数据系列中存在的复杂问题，以便更精准的进行预测。如文献[10]提出一种小波包变换（wavelet packet transform，WPT）和非参数（generalized auto regressive conditional heteroskedasticity，GARCH）混合模型对日前电价进行预测，实验表明，WPT 能很大程度提高预测精度。文献[11]提出一种基于小波变换（wavelet transform，WT）和遗传算法（genetic algorithm，GA）优化 SVM 新型混合模型。尽管现在很多单分解技术已广泛运用于预测问题上，如文献[12,13]中分别使用了经验模式分解（empirical mode decomposition，EMD）和集合经验模式分解。然而高频率本征模函数(intrinsic mode functions ，IMFs)，特别是 IMF1，很容易受到许多随机因素的影响[14]，从而加大了模拟难度。此外，本文发现由于很多非线性和非稳定性的原始序列导致了更多的高频率 IMFs 产生[15]，所以一层分解技术不能完全解决不规则数据系列。

为了解决上述问题，结合单分解技术的优势，本文采用了二层分解技术，提出了基于集合经验模式分解、变分模态分解和纵横交叉算法优化的神经网络组成的新型混合预测模型（EEMD-VMD-CSO-BP）来实现电价的多步预测。EEMD 将原始电价序列分解为一系列频率由高到低的 IMFs 和一个剩余量（Residual），为了减少数据序列的非稳定性，VMD 进一步将高频率 IMFs 分解为多个模态，并用纵横交叉算法（crisscross optimization algorithm，CSO）优化神经网络的权值和阈值来提高预测精度。本文分别以以澳大利亚的新南威尔士州和昆士南州的电力市场某月的电价数据作为样本，进行了一步、三步、五步电价预测，并对实验结果进行了分析。根据对比模型仿真结果表明，本文提出的混合模型预测精度高于其他混合模型。

## 1　EEMD-VMD-CSO-BP 混合模型

本文仿真数据分别来源于澳大利亚新南威尔士州（电力市场 1）和昆士南州（电力市场 2）的电力市场实测电价数据，由于不同区域有着不同的规模，如人口、地理位置、产业结构和气候特征，这些存在的不同因素导致了电价波动出现了很大的差异，因此本文采用二个电力市场的电价可以全面系统评估所提模型的有效性和实用性。本文以每半小时为 1 个数据点，每天共有 48 个观测值，根据这二个电力市场某月上旬记录电价值（共有 720 个观测值），可以得到图 1 所示新南威尔士州和昆士南州的电价序列，并利用原始序列前 600 个数据作为训练样本，对第 600~700 个电价数据进行预测。

本文所提出 EEMD-VMD-CSO-BP 混合模型基本框架如图 2 所示，所提混合模型主要框架是基于二层分解技术机制，以下提及实验仿真都是以电力市场 1 的半小时数据为例。详细步骤如下：

a)在第一层分解中，为了降低电价序列非线性和非平稳性的特点，EEMD 用于将原始电价序列分解为多个分量，可大概根据 EEMD-CSO-BP 混合模型的平均绝对百分比误差（mean absolute percentage error，MAPE）判断最佳分解个数，如图 3 所示，是 MAPE 随着分解个数变化的曲线，随着分解个数增加，MAPE 逐渐减小，但是在分解个数大于 8 的时候，预测误差稍微有点增加，所以本文模型中选择 EEMD 分解个数为 8，分别是 IMF1、IMF2、…、IMF7 和一个剩余量。如图 4 所示，IMFs 频率从高到低排列，每个 IMF 反映了存在于序列中的不同振荡模式，IMF1 是反映电价详细信息的最高频率信号，剩余量是频率最低的信号，显示了电价波动的基本趋势。

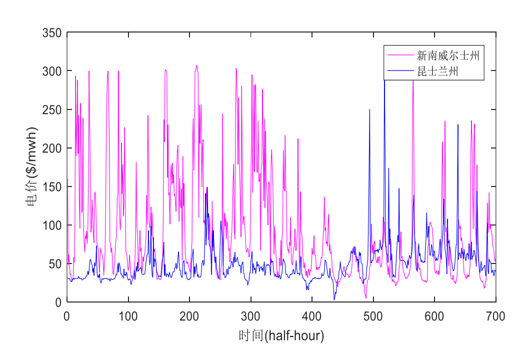


图 1　二个电力市场的原始电价序列

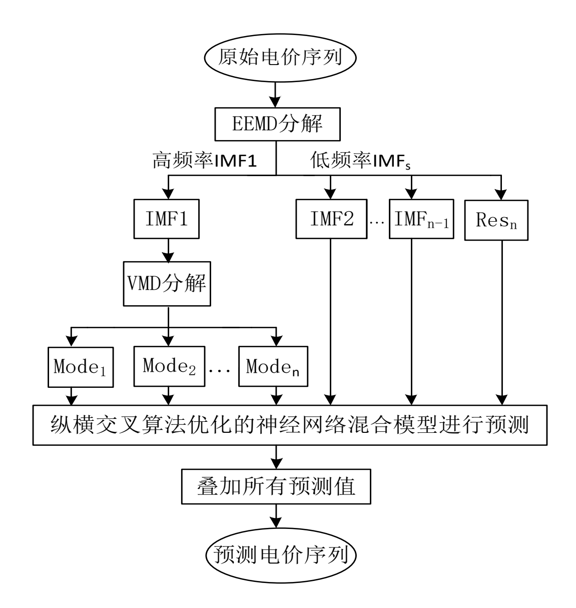


图 2　EEMD-VMD-CSO-BP 混合模型流程图

b)显而易见，在图 5 中，除了具有高频率振荡特性的 IMF1，含有很多噪声序列，其余 IMFs 和剩余量波动较平稳，且易能准确的预测，由于 IMF1 会增加预测难度，为了使预测效果更好，在第二层分解中，利用 VMD 将 IMF1 分解为多个模态分量，根据本文所提模型来大致判断 VMD 分解个数，如图 4 所示，当分解个数趋于 9 后 MAPE 处于相对平稳状态，所以大致选择分解个数为 9，分别是 mode1、mode2、…、mode8、mode9，如图 6 所示。

c)采用纵横交叉算法优化的神经网络模型对所有子序列进行预测，子序列包括 mode1、mode2、…、mode9、IMF2、…、IMF7、剩余量。叠加全部子序列预测值，所得值即实际预测电价值。

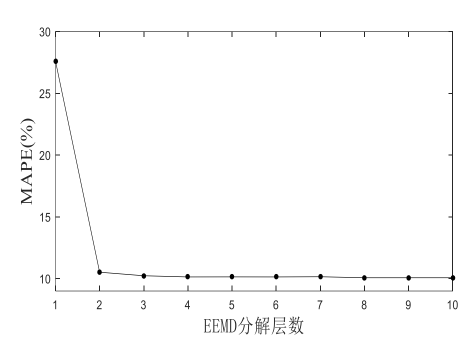



图 3　预测误差与 EEMD 分解层数变化图（电力市场 1）

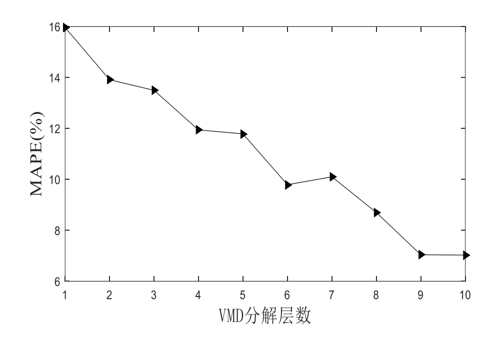



图 4　预测误差与 VMD 分解层数变化图（电力市场 1）

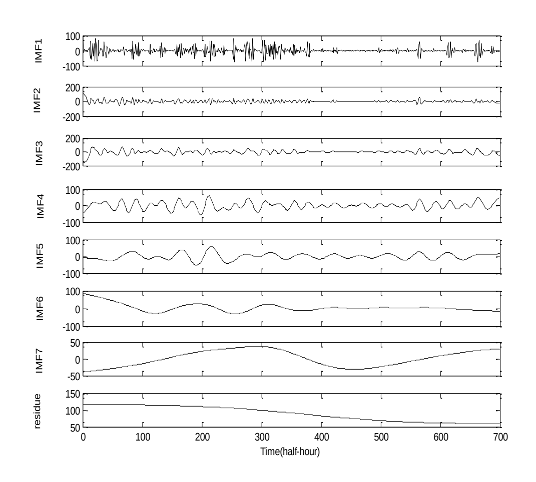



图 5　EEMD 分解电力市场 1 的原始电价数据

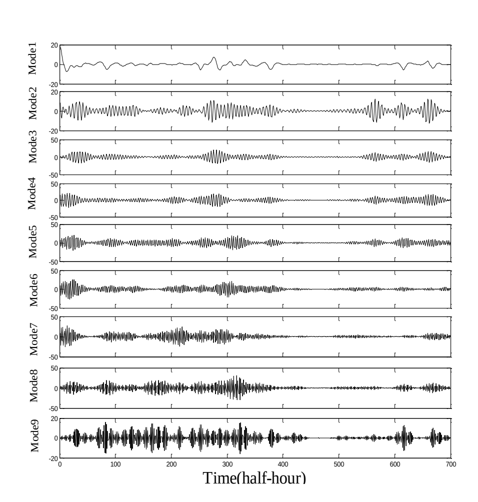



图 6　VMD 分解电力市场 1 中的 IMF1 序列

## 2　二层分解技术

### 2.1　集合经验模式分解

经验模式分解（empirical model decomposition, EMD）是一种自适应信号时频处理方法，适用于将非线性、非平稳的复杂信号分解为一些频率由高到低的本征模函数和一个剩余量。集合经验模式分解（EEMD）是在经验模式分解(EMD)的基础上进行改进，通过加入高斯白噪声这个变量，来处理经验模式分解中常遇到的模态混叠现象，并最大化保存了原始信号。本文 EEMD 分解中里的三个重要参数：白噪声 K、整合数 n、复制次数 M 分别设置为 0.4、9、200。EEMD 的详细原理参考文献[16]，具体分解步骤如下：

a)在原始数据序列中加入高斯白噪声。

b)将含有白噪声的 EMD 序列分解为多个 IMF 和一个剩余量。

c)通过加入不同的白噪声来重复步骤(1)和(2)，并得到相应的 IMF 和剩余量，重复次数即整合数 n。

d)将所有的 IMF 的均值和所有剩余量部分均值作为最终结果。

### 2.2　变分模态分解

变分模态分解（VMD）是 DRAGOMIRETSKIY 在 2014 年提出的一种新的非递归信号处理技术[17]，能够自适应将实值信号分解成一些拥有特定稀疏属性的离散模态。VMD 实质上是一个变分问题，为了处理该问题，可以将所有模态看做拥有不用中心频率的有限宽带，利用交替方向乘子法，逐步将所有模态调解到对应的基频带，最后得到各模态及各模态对应的中心频率。为了评估每个模式的频宽，应该考虑以下步骤：

a)对于原始信号 $f(t)$，利用 Hilbert 变换进行时频处理，进而获得每个模态函数 $u_k(t)$ 的解析信号，以及 $u_k(t)$ 的单边频谱。

b)为了使每个模态的频谱调制到基带上，则在 $u_k(t)$ 中混合了相应的指数项，使得调整到所估计的中心频率。

c)使用以上已调解信号的高斯平滑度 H1 来计算每个模态的带宽。因此，得到一个变分约束问题：

$$\min_{\{u_k\},\{w_k\}}\left\{\sum_k\left\|\partial_t\left[\left(\partial(t)+\frac{j}{t\pi}\right)u_k(t)\right]e^{-jw_k t}\right\|_2^2\right\}\qquad(1)$$
$$s.t\sum_k u_k = f(t)$$

在式(1)中，$f(t)$是原始数据信号，$\{u\}$是分解后获得的 K 个模态分量，其中 $\{u_k\}=\{u_{1,\ldots,}u_K\}$；$\{w\}$为每个模态对应的中心频率，其中 $\{w_k\}=\{w_{1,\ldots,}w_K\}$；$k=1,2,3\cdots K$。考虑到惩罚项和拉格朗日乘数 k，可以将上式转换为无约束问题，形成了扩展拉格朗日表达式，如式(2)所示。

$$L(\{u_k\},\{w_k\},\lambda)=a\sum_k\left\|\partial_t\left[\left(\partial(t)+\frac{j}{t\pi}\right)u_k(t)\right]e^{-jw_kt}\right\|_2^2+\left\|f(t)-\sum_k u_k(t)\right\|_2^2+\left\langle\lambda(t),f(t)-\sum_k u_k(t)\right\rangle \quad (2)$$

其中：$a$ 为数据保真度约束的平衡参数，可以在噪声存在的情况下也能保持重构的准确性，$\lambda(t)$ 是拉格朗日算子。通过 ADMM 方法在每次迭代优化中可以找到上式表达式的鞍点[18]，也就是式(1)中的最优解。其中 $u_k$ 和 $w_k$ 的表达式如下：

$$\hat{u}_k^{n+1}(w)=\frac{\hat{f}(w)-\sum_{i\neq k}\hat{u}_i(w)+\frac{\hat{\lambda}(w)}{2}}{1+2a(w-w_k)^2}$$
$$w_k^{n+1}=\frac{\int_0^\infty w|\hat{u}_k(w)|^2dw}{\int_0^\infty|\hat{u}_k(w)|^2dw} \quad (3)$$

其中：$w$ 为信号频率，n 表示迭代次数，$\hat{f}(w)$、$\hat{u}_i$、$\hat{u}_k^{n+1}(w)$、$\hat{\lambda}(w)$ 分别是 $f(t)$、$u_i(t)$、$u_k^{n+1}(t)$、$\lambda(t)$ 的傅里叶变换。

## 3　纵横交叉优化算法

纵横交叉算法（CSO）是由横向交叉和纵向交叉两种算子组成。每次迭代过程中，都会进行横向交叉和纵向交叉，交叉后得到的子代称为中庸解（$MS_{hc}$，$MS_{vc}$）。所得到的子代与其父代相比，保留适应度更好的解，称为占优解（横向交叉占优解 $DS_{hc}$，纵向交叉占优解 $DS_{vc}$）。

### 3.1　横向交叉操作

横向交叉与遗传算法中的交叉相似，横向交叉（横向交叉概率通常取 1）是在两个粒子中做算数交叉操作，且两粒子是在同一维随机产生。与传统交叉相比较，加强了局部最优粒子的边缘搜索能力，增大了搜索的范围。交叉后产生的子代公式如下：

$$MS_{hc}(i,d)=r_1\times X(i,d)+(1-r_1)\times X(j,d)+c_1\times(X(i,d)-X(j,d)) \quad (4)$$

$$MS_{hc}(j,d)=r_2\times X(j,d)+(1-r_2)\times X(i,d)+c_2\times(X(j,d)-X(i,d)) \quad (5)$$

$$i,j\in N(1,M),\qquad d\in N(1,D)$$

其中：$r_1$、$r_2$ 是 $[0,1]$ 的随机数；$c_1$、$c_2$ 是 $[-1,1]$ 中的随机数；$M$ 为粒子数的范围；$D$ 为变量的维数；$X(i,d)$、$X(j,d)$ 各自代表父代粒子 $X(i)$ 和 $X(j)$ 的第 $d$ 维；$MS_{hc}(i,d)$、$MS_{hc}(j,d)$ 各自代表 $X(i,d)$ 和 $X(j,d)$ 进行横向交叉后得到的第 $d$ 维子代。

以社会学的角度来看，式(4) (5)的第一项是粒子此时最好的值，第二项表示父代粒子相互作用。前二项通过 $r_1$（惯性权重因子）较好的结合在一起。式(4)(5)中的第三项以较小的概率在种群边缘寻优，增大了搜索范围。得到的子代将与父代相比较，选择适应度更好的保留在占优解 $DS_{hc}$ 中，并进行下一次迭代。

### 3.2　纵向交叉操作

纵向交叉操作为了使陷入局部最优的粒子跳出来，而又不干扰其他维的粒子。由于不同维所处范围不同，因此在交叉前必须对种群中的所有维进行归一化处理。每次纵向交叉操作后产生的子代公式如下：

$$MS_{vc}(i,d_1)=r\cdot X(i,d_1)+(1-r)\cdot X(i,d_2) \quad (6)$$

$$i\in N(1,M),d_1,d_2\in N(1,D),r\in[0,1]$$

其中：$MS_{vc}(i,d_1)$ 是粒子 $X(i)$ 的第 $d_1$ 维和第 $d_2$ 维进行纵向交叉得到的子代。纵向交叉概率 $p_v$（一般取 0.2～0.8）交叉操作后能使粒子摆脱局部最优的状况，交叉后进入竞争机制，将产生的子代与其父代粒子比较，选择优秀粒子保留在 $DS_{vc}$ 中。

## 4　纵横交叉算法优化神经网络

BP 神经网络[19]是指基于产生误差反向传播算法的前馈神经网络，它是由输入层、隐含层、输出层组成的三层网络结构，隐含层的功能是连接输入和输出。由于其具有良好的自学习能力和噪声容限，已广泛应用于不同的预测领域。由于 BP 神经网络在预测过程中，采用梯度下降法调整权值和阈值，经常会出现陷入局部最优的问题，随着干扰因素和样本数据逐渐增加时，神经网络参数计算量也会急剧增加，收敛速度也将变缓。而 CSO 算法全局搜索效果较好，能很大程度上提高神经网络的预测能力，如图 7 所示，是两种模型的 1 步预测最优收敛曲线，且 CSO-BP、PSO-BP 两种模型的种群大小和迭代次数设置一致，实验数据都是来电力市场 1。

假设神经网络输入层，隐含层和输出层的节点数是 $n$、$h$、$m$，变量维数 $D=n\times h+m\times h+h+m$。每个粒子的适应值使用如下均方误差公式（适应度函数）来获得：

$$fit=\frac{1}{N}\sum_{k=1}^{N}\sum_{t=1}^{m}(p_t-\hat{p}_t)^2 \quad (7)$$

其中：$p_t$ 表示神经网络的实际输出，$\hat{p}_t$ 表示神经网络的目标输出，$N$ 表示训练样本数。

CSO 优化神经网络的过程概括如下：

a)按照本文实验的训练样本，确定 BP 的层数和各层的神经元数目，并进行实数编码。

b)确定本文中主要参数:种群规模、最大迭代次数、纵向交叉概率 $p_v$。在编码的解空间中，随机生成初始种群 $X$。

c)结合式(7)计算群体中所有粒子的适应值。

d)按照式(4)(5)进行横向交叉操作，获得的子代保存在矩阵 $MS_{hc}$ 里面，再计算该矩阵里所有粒子的适应值，将得到的结果与父代 $X$（即 $DS_{vc}$，第一代除外）对比，选出适应度更好的粒子保留在 $DS_{hc}$ 中。

e)根据式(6)进行纵向交叉后产生的解保存在矩阵 $MS_{vc}$ 中，然后计算 $MS_{vc}$ 每个粒子的适应值，与其父代 $X$ (即 $DS_{hc}$)对比，选择更优秀的粒子保留在 $DS_{vc}$ 中。

f)判断是否达到设定的要求。如果迭代次数大于所设定的最大迭代值，则迭代结束。并将 $DS_V$ 中适应度最好的一组解设为为神经网络所对应的权值和阈值。否则，转到步骤 d)再一次迭代。

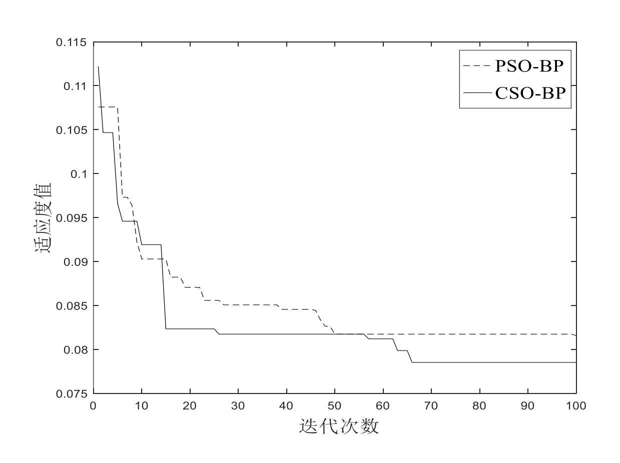



图 7　不同算法最优收敛曲线

## 5　算例分析

为了验证本文所提模型 EEMD-VMD-CSO-BP 在一步和多步电价预测中的有效性，因此进行了以下二项实验研究加以证明，所有模型的迭代次数设为 100，种群大小 M 设为 20，且神经网络参数均设置相同。在第一项实验中，以新南威尔士州的电价数据作为实验数据，使用所提模型的组成部分：BP、CSO-BP、VMD-CSO-BP 和 EEMD-CSO-BP 被选为基准模型，与本文模型进行对比，验证了混合策略的性能，在第二项实验中，为了全面评估所提模型，本文分别以新南威尔士州和昆士南州电价为实验数据，将三个现有模型，包括 WT-GA-SVM、EMD-GA-BP 和 PSO-BP 与本文模型进行比较。另外，采用了三种标准来评估所有模型的预测效果，如式 8、式 9、式 10 分别是平均绝对误差（mean absolute error，MAE）、均方根误差（root mean square error，RMSE）以及 MAPE 的表达式。

$$MAE=\frac{1}{N}\sum_{t=1}^{N}\left|X(t)-\hat{X}(t)\right| \tag{8}$$

$$RMSE=\sqrt{\frac{1}{N}\sum_{t=1}^{N}\left(X(t)-\hat{X}(t)\right)} \tag{9}$$

$$MAPE=\frac{1}{N}\sum_{t=1}^{N}\left|\frac{X(t)-\hat{X}(t)}{X(t)}\right|\times 100\% \tag{10}$$

其中：N 表示测试的数据数目，$X(t)$ 是指在时间为 t 时候的实际电价值，$\hat{X}(t)$ 是指在 t 时刻的预测电价值。

表 1 显示了本文模型和基准模型在一步和多步预测中的预测误差，显然本文模型的 MAE、RMSE、MAPE 在一步（S1）、三步(S2)、五步(S3)中的值最小，所示结果证明了本文模型的分解技术最好，为了进一步分析本文提出的二层分解技术和 CSO 优化算法的混合模型所具有的优势，在本项实验中进行了以下三类比较，对比了不同模型在单步预测中误差结果，如表 2 所示。

第一类比较：VMD-CSO-BP 模型和 EEMD -CSO-BP 模型相比 CSO-BP 模型平均百分比误差分别减少了 46%和 62%，结果显示了单分解技术的优势。

第二类比较：EEMD-VMD-CSO-BP 模型相比 VMD-CSO-BP 模型和 EEMD-CSO-BP 模型平均百分比误差分别减少了 51%和 30%，所以本文提出的二层分解技术优于单分解技术，此外，由图 8-10 可以看出，随着步长的增加，二层分解技术对预测精度影响越来越小，原因是由于步长的增加，除 IMF1 外的其他 IMF 形成了误差的累积，因此在第二层分解中 VMD 对提高预测精度的作用会越来越大。

第三类比较：CSO-BP 模型较 BP-NN 模型的平均百分比误差减少了 11%：说明 CSO 算法对神经网络产生了积极的影响，通过优化 BP 的参数，使其产生接近最优的权值和阈值，从而拥有更高的预测精度。

在第二项实验研究中，所有预测结果如表 3 所示，显然本文模型在一步三步五步中预测误差最小，且分别在不同的电力市场都适用，进一步证明了所提模型在预测能力上较其他混合模型具有明显的优势。

表 1　不同模型的预测性能分析（电力市场 1）

| 预测步长 | 1 步 | 3 步 | 5 步 |
|---|---|---|---|
| | BP-NN 预测模型 | | |
| MAE | 24.54 | 31.23 | 31.45 |
| RMSE | 40.99 | 46.23 | 47.77 |
| MAPE(%) | 29.43 | 45.67 | 47.86 |
| | CSO-BP-NN 预测模型 | | |
| MAE | 22.51 | 29.81 | 30.01 |
| RMSE | 37.75 | 40.34 | 42.66 |
| MAPE(%) | 26.85 | 41.76 | 44.42 |
| | EEMD-CSO-BP 预测模型 | | |
| MAE | 8.62 | 12.82 | 15.25 |
| RMSE | 15.58 | 22.45 | 26.56 |
| MAPE(%) | 10.11 | 18.90 | 24.21 |
| | VMD-CSO-BP 预测模型 | | |
| MAE | 7.81 | 8.22 | 9.05 |
| RMSE | 10.69 | 11.99 | 13.30 |
| MAPE(%) | 14.58 | 15.01 | 15.88 |
| | EEMD-VMD-CSO-BP 预测模型 | | |
| MAE | 3.97 | 5.55 | 7.69 |
| RMSE | 5.60 | 7.76 | 10.34 |
| MAPE(%) | 7.04 | 9.62 | 14.85 |

表 2　表 1 中的单步预测结果对比（电力市场 1）

| 模型 | MAE(%) | RMSE(%) | MAPE(%) |
| --- | --- | --- | --- |
| EEMD-VMD-CSO-BP vs. VMD-CSO-BP | 49% | 53% | 51% |
| EEMD-VMD-CSO-BP vs. EEMD-CSO-BP | 54% | 64% | 30% |
| VMD-CSO-BP vs. CSO-BP-NN | 65% | 72% | 46% |
| EEMD-CSO-BP vs. CSO-BP-NN | 62% | 58% | 62% |
| CSO-BP-NN vs. BP-NN | 8% | 10% | 11% |

表 3　本文模型与已存在模型的预测性能对比

| | | EEMD-VMD-CSO-BP | | | WT-GA-SVM | | |
| --- | --- | --- | --- | --- | --- | --- | --- |
| | | S1 | S3 | S5 | S1 | S3 | S5 |
| | MAE | 3.97 | 5.55 | 7.69 | 10.28 | 15.67 | 20.63 |
| | RMSE | 5.60 | 7.76 | 10.34 | 16.42 | 22.49 | 33.38 |
| | MAPE | 7.04 | 9.62 | 15.01 | 13.25 | 19.31 | 26.63 |
| 电力市场 | | EMD-GA-BP | | | PSO-BP | | |
| 1 | | S1 | S3 | S5 | S1 | S3 | S5 |
| | MAE | 18.56 | 25.79 | 30.21 | 21.17 | 34.26 | 45.96 |
| | RMSE | 20.59 | 33.77 | 38.25 | 30.52 | 42.52 | 55.95 |
| | MAPE | 15.50 | 21.92 | 29.96 | 24.15 | 32.37 | 41.69 |
| | | EEMD-VMD-CSO-BP | | | WT-GA-SVM | | |
| | | S1 | S3 | S5 | S1 | S3 | S5 |
| | MAE | 3.27 | 5.29 | 8.68 | 9.51 | 13.29 | 19.53 |
| | RMSE | 4.73 | 7.48 | 12.05 | 13.93 | 20.41 | 30.64 |
| | MAPE | 5.48 | 8.50 | 13.88 | 11.22 | 18.67 | 24.21 |
| 电力市场 | | EMD-GA-BP | | | PSO-BP | | |
| 2 | | S1 | S3 | S5 | S1 | S3 | S5 |
| | MAE | 14.44 | 21.56 | 27.24 | 19.78 | 33.86 | 42.35 |
| | RMSE | 16.51 | 28.78 | 34.76 | 28.60 | 40.55 | 53.44 |
| | MAPE | 12.20 | 18.37 | 27.13 | 22.99 | 30.86 | 40.57 |

## 6　结束语

本文首先分析了电价预测对电力市场的风险评估与决策管理等意义重大，并对已存在的预测模型进行了分析，鉴于此，提出一种基于 EEMD-VMD-CSO-BP 新型混合模型对电价进行多步预测，模型主要分为数据预处理和预测两部分，根据实验结果，可以发现二层分解技术在提高模型的预测能力上优于单分解模型，CSO 算法对 BP 模型产生了积极影响，通过优化其输入层和隐含层的权值和阈值，从而提高预测精度。与本文所提其他混合模型相比，EEMD-VMD-CSO-BP 混合模型具有最佳性能，表明所提模型非常适用于非稳定性电价预测。

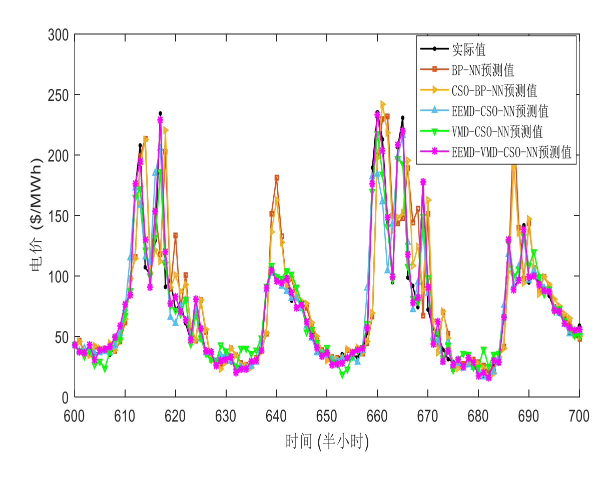



图 8　提前一步电价预测结果（电力市场 1）

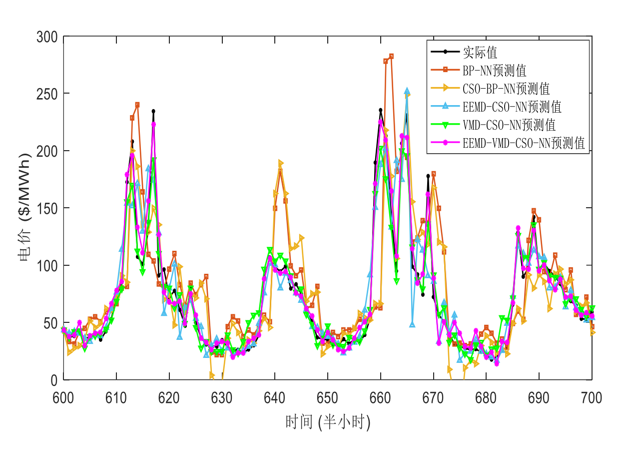



图 9　提前三步电价预测结果（电力市场 1）

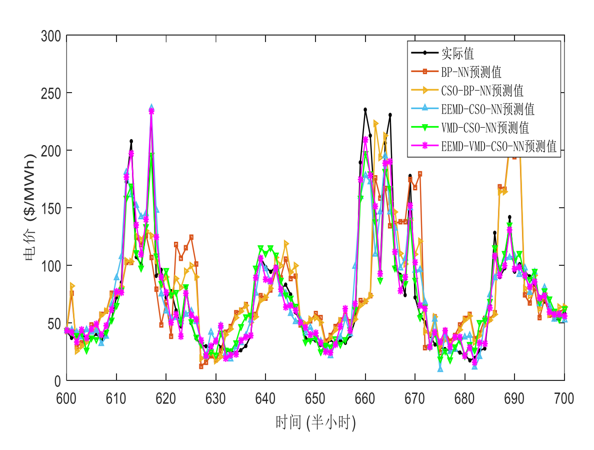



图 10　提前五步电价预测结果（电力市场 1）

## 参考文献：

[1] 熊尚飞，邹小燕．电力市场价格风险价值与波动预测研究综述 [J]．电力系统保护与控制，2014 (2): 146-153.

[2] Weron R. Electricity price forecasting: A review of the state-of-the-art with a look into the future [J]. International Journal of Forecasting, 2014, 30 (4): 1030-1081.
[3] 张显，王锡凡. 分时段短期电价预测 [J]. 中国电机工程学报, 2005, 25 (15): 1-6.
[4] He K, Yu L, Tang L. Electricity price forecasting with a BED (Bivariate EMD Denoising) methodology [J]. Energy, 2015, 91: 601-609.
[5] Santos N, Rui R. Performance of state space and ARIMA models for consumer retail sales forecasting. [M]. Pergamon Press, Inc. 2015.
[6] Lei M, Luan S, Jiang C. A review on the forecasting of wind speed and generated power. Renewable & Sustainable Energy Reviews, 2009, 13 (4): 915-920.
[7] Panapakidis I P, Dagoumas A S. Day-ahead electricity price forecasting via the application of artificial neural network based models [J]. Applied Energy, 2016; 172: 132-151.
[8] 任洪娥，霍满冬. 基于 PSO 优化的 SVM 预测应用研究 [J]. 计算机应用研究, 2009, 26 (3): 867-869.
[9] 杨波，赵遵廉，陈允平，等. PSO 演化神经网络集成的边际电价预测新方法 [J]. 高电压技术, 2007, 33 (10): 162-166.
[10] 邓佳佳，黄元生，宋高峰. 基于非参数 GARCH 的时间序列模型在日前电价预测中的应用 [J]. 电网技术, 2012, 36 (4): 190-196.
[11] WANG JZ, WANG Y, JIANG P. The study and application of a novel hybrid forecasting model: a case study of wind speed forecasting in China [J]. Applied Energy, 2015; 143: 472–88.
[12] 刘兴杰，米增强，杨奇逊，等. 一种基于 EMD 的短期风速多步预测方法 [J]. 电工技术学报, 2010, 25 (4): 165-170.
[13] 陈文驰，刘飞. 一种基于 EEMD 的过程数据混合去噪方法 [J]. 计算机应用研究, 2012, 29 (4): 1368-1370.
[14] Liu Z, Sun W, Zeng J. A new short-term load forecasting method of power system based on EEMD and SS-PSO [J]. Neural Computing & Applications, 2014, 24 (3-4): 973-983.
[15] Huang S Z, Chang J X, Huang Q, et al. Monthly stream flow prediction using modified EMD-based support vector machine [J]. Journal of Hydrology, 2014, 511 (7): 764-775.
[16] Zhaohua W U, Huang N E. Ensemble empirical mode decomposition: a noise-assisted data analysis method [J]. Advances in Adaptive Data Analysis. 2009. 1 (1): 1-41.
[17] Dragomiretskty K, Zosso D. Variational mode decomposition [J]. IEEE Trans on Signal Processing, 2014, 62 (3): 531-544.
[18] Carrion M, Arroyo J M, Conejo A J. A bilevel stochastic programming approach for retailer futures market trading [J]. IEEE Trans on Power Systems, 2009, 24 (3): 1446-1456.
[19] 盛立，刘希玉，高明. 一种新的全局优化 BP 网络 [J]. 计算机应用研究, 2006, 23 (2): 211-212.
[20]